

Е-STGCN: усовершенствованная сверточная нейронная сеть на основе пространственно-временных графов для прогнозирования дорожного трафика

О.К. Головнин¹, Н.Д. Перевозчиков¹

¹Самарский национальный исследовательский университет им. академика С.П. Королева, Московское шоссе 34а, Самара, Россия, 443086

Аннотация

В статье предложена усовершенствованная сверточная нейронная сеть с пространственно-временными графами (Е-STGCN), предназначенная для прогнозирования характеристик транспортных потоков. Усовершенствование нейросети выполнено путем введения дополнительной оценки критериев, учитывающей взаимовлияние транспортных потоков на смежных участках улично-дорожной сети. Выполнена оценка эффективности предложенной Е-STGCN по сравнению с LSTM-сетью и STGCN на наборе данных CityPulse. Предложенная Е-STGCN имеет меньшую ошибку прогнозирования, чем LSTM-сеть и STGCN.

Ключевые слова

Е-STGCN, STGCN, сверточная нейросеть, пространственно-временной граф

1. Введение

Потребность в эффективном прогнозировании характеристик транспортных потоков нарастает в свете развития и внедрения передовых интеллектуальных транспортных систем и технологий [1, 2]. С накоплением достаточных наборов данных для машинного обучения наименьшую ошибку прогнозирования дорожного трафика стали показывать сверточные нейронные сети на основе пространственно-временных графов (STGCN) [3, 4].

В этой статье предложена усовершенствованная STGCN (Е-STGCN), позволяющая учесть взаимосвязи между смежными участками улично-дорожной сети (УДС), для чего вводится дополнительная оценка критериев при расчете матрицы смежности с учетом важности того или иного участка УДС.

2. Архитектура Е-STGCN

За основу предлагаемой Е-STGCN взят каркас STGCN, состоящий из двух пространственно-временных блоков свертки и выходного слоя [3]. Каждый блок пространственно-временной свертки содержит два временных стробированных сверточных слоя и один пространственный граф посередине. В STGCN матрица смежности вычисляется на основе расстояния между точками в транспортной сети и не учитывает другие виды связей между участками УДС (топологические, функциональные, логические и др.). В предложенной Е-STGCN вносятся изменения в правила формирования матрицы смежности: в основе вершин формируемого графа транспортной сети лежат конкретные участки УДС, при этом вес ребра в матрице смежности описывает связь между двумя участками УДС.

Таким образом, матрица смежности W позволяет судить о взаимосвязи между вершинами графа:

$$W = (w_{i,j}) = \begin{cases} f(e_{i,j}), & i \neq j; \\ 0, & \text{иначе;} \end{cases} \quad (1)$$

где $w_{i,j}$ – вес ребра, определяемый функцией f ; $e_{i,j}$ – ребро, соединяющее участки УДС с номерами i и j .

При этом функция f примет следующий вид:

$$f(e_{i,j}) = \sum_{k=1}^K \alpha_k \cdot (u_k(\theta_i) + u_k(\theta_j)), \quad (2)$$

где α_k – весовой коэффициент, показывающий уровень значимости влияния u_i в рамках текущей решаемой задачи; u_k – числовое значение влияния связи с номером k на текущем участке УДС θ . Например, одной из характеристик участка УДС может выступать количество съездов и въездов на другой участок УДС. В таком случае значение веса для соединяющего их ребра будет больше в том случае, при котором возможностей для прохождения транспортного потока больше, что соответствует реальной дорожной ситуации.

3. Программная реализация и результаты

Предлагаемая E-STGCN для прогнозирования трафика реализована на языке программирования Python. Программная реализация позволяет учитывать влияние различных факторов на скорость, плотность и интенсивность трафика, изменяя коэффициенты в (2).

Для сравнительной оценки полученных с помощью E-STGCN результатов использованы две нейросети: нейросеть с LSTM-ячейками и классическая STGCN. Использован набор данных CityPulse [5] и установлен горизонт прогноза в 30 мин., при этом E-STGCN учитывала только съезды/выезды. Полученные ошибки прогнозирования приведены в Таблице 1.

Таблица 1

Сравнение эффективности подходов

Нейросеть	Среднеквадратическая ошибка	Средняя абсолютная ошибка	Средняя абсолютная процентная ошибка
LSTM	5,67	3,46	9,44
STGCN	3,76	2,45	8,02
E-STGCN	3,73	2,44	8,00

Так, LSTM-нейросеть показывает худшие результаты, в то время как E-STGCN незначительно превосходит показатели STGCN, однако при учете большего числа факторов точность E-STGCN возрастает.

4. Заключение

Таким образом, предложенная E-STGCN позволит использовать наиболее полезные пространственные и временные факторы в процессе прогнозирования дорожного трафика.

5. Литература

- [1] Агафонов, А.А. Анализ больших данных в геоинформационной задаче краткосрочного прогнозирования параметров транспортного потока на базе метода k ближайших соседей / А.А. Агафонов, А.С. Юмаганов, В.В. Мясников // Компьютерная оптика. – 2018. – Т. 42, № 6. – С. 1101-1111. DOI: 10.18287/2412-6179-2018-42-6-1101-1111.
- [2] Golovnin, O. Detailed models and network-centric technologies of transport process management / O. Golovnin, T. Mikheeva // 5th IEEE Int. Conf. on Models and Technologies for Intelligent Transportation Systems. – 2017. – P. 768-773.
- [3] Yu, B. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting / B. Yu, H. Yin, Z. Zhu // Proc. of the 27th Int. Joint Conf. on Artificial Intelligence. – 2018. – P. 3634-3640.
- [4] Wang, C. Auto-STGCN: Autonomous spatial-temporal graph convolutional network search based on reinforcement learning and existing research results / C. Wang // ArXiv preprint: 2010.07474. – 2020.
- [5] CityPulse Smart City Datasets [Electronic resource]. – Access mode: <http://iot.ee.surrey.ac.uk:8080/datasets.html> (26.01.2021).